

文章编号: 1007 4619(2007)01 0048 07

# 基于多尺度特征融合和支持向量机的高分辨率遥感影像分类

黄 昕, 张良培, 李平湘

(武汉大学 测绘遥感信息工程国家重点实验室, 湖北 武汉 430079)

**摘 要:** 相对传统的中低分辨率遥感数据而言, 高空间分辨率遥感影像同一地物内部丰富的细节得到表征, 空间信息更加丰富, 地物的尺寸、形状以及相邻地物的关系得到更好的反映, 但其光谱统计特性不如中低分辨率影像稳定, 类内光谱差异较大, 而传统分类方法仅依据像元的光谱值, 因此在高分辨率影像分类中, 传统方法往往不能获得好的结果。在此背景下, 提出了一种多尺度空间特征融合的分类方法, 旨在利用不同尺度的空间邻域特征弥补传统方法的不足。其基本过程是: 首先针对不同尺度特点, 用小波变换压缩空间邻域特征, 并结合支持向量机得到不同尺度下的分类结果, 然后根据尺度选择因子为每个像元选择最佳的类别。文中 QuickBird 和 IKONOS 影像实验证明该算法能有效提高高分辨率影像解译的精度。

**关键词:** 多尺度; 融合; 支持向量机; 高分辨率

**中图分类号:** TP751.1      **文献标识码:** A

## Classification of High Spatial Resolution Remotely Sensed Imagery Based Upon Fusion of Multiscale Features and SVM

HUANG Xin ZHANG Liang pei LI Ping-xiang

(National Key Laboratory for Information Engineering in Surveying Mapping and Remote Sensing  
Wuhan University Hubei Wuhan 430079 China)

**Abstract** A new classification algorithm for high spatial resolution remotely sensed imagery is proposed which integrates neighborhood information of multiscale such as  $2 \times 2$ ,  $4 \times 4$ ,  $8 \times 8$  and  $16 \times 16$  window sizes around the central pixel. In order to compress the information of the multiscale spatial features, a wavelet coefficients fusion algorithm is employed to reduce the dimension but retain the spatial information at the same time. After the stage of multiscale neighborhood feature extraction, a good tool of pattern recognition SVM is employed to process the multiscale features. In this algorithm, four groups of spatial features based on four scales produce four classification maps. And then, these maps, which represent multiscale classification results, are fused by a scale selection parameter. The final fusion map is the result of multiscale features classification and shows an obvious adaptability to objects of different scales. Experiments of QuickBird and Ikonos show that the proposed classification algorithm of multiscale features fusion can achieve better results and better accuracies than the conventional per pixel multispectral method.

**Key words** multiscale; feature fusion; SVM; high spatial resolution

收稿日期: 2005-11-29 修订日期: 2006-01-06  
基金项目: 国家自然科学基金(编号: 40471088 40523005), 国家 973 计划资助项目(编号: 2006CB701302)。  
作者简介: 黄 昕(1982—), 男, 博士研究生, 主要从事高分辨率遥感影像模式识别、神经网络原理、遥感应用等方面的研究。E-mail: huangxin1982420@163.com.

# 1 引 言

遥感对地观测是人类获取地球空间信息的重要手段, 传感器技术的发展使我们可以得到高空间分辨率影像, 在轨运行的 QuickBird 和 KONOS 分别可以获得 0.61m 和 1m 分辨率的数据。这种新型影像为地物观测提供了更丰富的信息和细节, 地物的尺寸、形状以及相邻地物的关系得到更好的反映, 这使其在城市环境、精准农业、交通及道路设施、林业、军事等领域中有着广泛的应用前景。

随着影像空间分辨率的提高, 地物的光谱分布更具变化, 不同地物的光谱相互重叠, 数据量大幅度增加, 地物信息呈现高度细节化。而现有的解译方法是建立在中低分辨率影像的基础上的, 传统的光谱方法无法有效解译高分辨率遥感数据, 因此这类新型遥感影像的分类技术已成为当前遥感领域的研究热点, 科研人员也对此进行了不懈的探索: Myint<sup>[1]</sup> 利用小波提取区域的纹理特征以弥补光谱特征的不足; Jimenez<sup>[2]</sup> 把光谱特征空间扩大到邻域进行分类决策, 利用邻域信息辅助分类; Christodoubs<sup>[3]</sup> 利用多元化纹理特征增加特征空间的维数以提高模式的可行性; Konoes<sup>[4]</sup> 认为核空间可能产生低维光谱特征所不具备的新特征, 从而提高高分辨率影像的分类精度; Barnsley<sup>[5]</sup> 对逐像素多光谱的分类结果进行后处理, 用像元类别在空间的排列规则结合先验知识进行重分类, 得到了优于光谱分类的结果。

总结近年来高分辨率遥感影像模式识别的研究进展可以发现, 这类新型遥感影像的解译需要借助空间邻域特征和更合理的决策机制。本文提出一种邻域多尺度特征融合算法, 提取多尺度下不同邻域的空间特征, 并结合支持向量机这一具有核映射能力的模式识别工具进行分类, 然后根据不同尺度的特点进行决策层融合。实验证明, 该算法相对于传统的光谱方法具有明显的优势, 同时具备较强的实用性。

## 2 理论与算法

传统分类方法仅仅对影像的最小单元——像元进行处理, 然而像元层次上的统计分析不可能进行相关的思维和推理活动, 也不可能实现较高层次的遥感影像理解和分析, 要提高分类精度, 必须突破像元层次上的遥感分类体系<sup>[6]</sup>。高分辨率遥感影像

像元之间的联系更为紧密, 这类影像的解译要考虑以下几个因素: (1) 地物的光谱分布规律变得不明显, 类内(光谱分布)方差增大, 类间方差减小, 单像素的光谱值在分类中的可信度降低, 其模式分类需要借助区域内的上下文信息; (2) 高分辨率影像充分揭示了地物的细节, 这为某些特定目标的识别带来便利, 但对于某些大面积同质性地物而言, 分辨率的提高并不意味着解译精度的提高; (3) 现有的高分辨率传感器所能获取的光谱波段数较少, 这也限制了传统光谱方法的应用。所以这类影像的理解需要在分类单元和特征上做出相应的调整, 针对问题(1), 本文把像素的特征空间扩展到邻域, 并针对空间特征维数过高的缺点, 用小波变换提取并压缩像元的空间信息; 针对问题(2)和(3), 本文引入支持向量机解译空间特征, 并提出多尺度特征融合算法, 对不同尺度的地物用不同尺度的空间特征进行分类决策。

### 2.1 多尺度特征提取

本文的多尺度特征提取算法有两个特点:

(1) 多窗口设置 用中心像元的一系列不同大小的窗口作为该像元的多尺度度量单位, 如图 1 所示, 不同尺度的信息通过以该像元为中心的  $2 \times 2$ 、 $4 \times 4$ 、 $8 \times 8$  和  $16 \times 16$  邻域进行描述。采取这种多窗口策略是为了模拟人的视觉对不同结构、形状和尺度的目标的识别方式, 用一定区域范围的背景邻域来确定像素的性质和特征。




图 1 像元邻域的多尺度描述

Fig 1 Multiscale description of a pixel around its neighborhood

(2) 空间特征维数减少 先用 PCA 变换提取多光谱影像的第一主成分, 高分辨率影像的光谱波段较少, 所以这一步处理损失的光谱信息较少。然后提取第一主成分影像中像元的空间邻域特征。如果以窗口内所有像元的灰度值序列作为特征, 则有主次不分的弊端, 因为只有当前的中心像元是待识别的, 而且特征维数过高反而对分类不利。本文利用

小波变换提取窗口的空间特征,同时降低邻域特征的维数。二维影像  $f(x,y)$  在分辨率  $2^j$  下的小波系数可按下式计算:

$$\left. \begin{aligned} c_{m,n}^{(j)} &= \sum_k \phi_{k-2m} \psi_{l-2n} f_{k,l}^{j-1} \\ w_{m,n}^{(j,h)} &= \sum_k \phi_{k-2m} \psi_{l-2n} f_{k,l}^{j-1} \\ w_{m,n}^{(j,v)} &= \sum_k \psi_{k-2m} \phi_{l-2n} f_{k,l}^{j-1} \\ w_{m,n}^{(j,d)} &= \sum_k \psi_{k-2m} \psi_{l-2n} f_{k,l}^{j-1} \end{aligned} \right\} \quad (1)$$

式中,  $c_{m,n}^{(j)}$ ,  $w_{m,n}^{(j,v)}$ ,  $w_{m,n}^{(j,h)}$  和  $w_{m,n}^{(j,d)}$  分别表示低频、水平高频、垂直高频和对角高频子带的小波系数,  $j$  为小波分解阶数,  $\psi(x)$  为一维小波函数,  $\phi(x)$  为一维尺度函数。实验选用 *db3* 小波基, 算法步骤为:

Step(1) 取以像元  $(x,y)$  为中心的多窗口区域如  $2 \times 2$   $4 \times 4$   $8 \times 8$  和  $16 \times 16$  存放于数组中。

Step(2) 每阶小波变换会产生 4 个子频带, 所以每次压缩过程中存在小波系数选择的问题, 其原则是在保存区域主要信息的同时, 也不忽视细节信息和边缘特征。设  $L(i,j)$ ,  $H(i,j)$ ,  $V(i,j)$  和  $D(i,j)$  分别为 4 个子频带中相应位置上的小波系数,  $C(i,j)$  为系数选择的结果, 可按加性融合或极大值融合:

$$C(i,j) = \begin{cases} \max(L(i,j), H(i,j), V(i,j), D(i,j)) & \text{最大值融合} \\ L(i,j) + H(i,j) + V(i,j) + D(i,j) & \text{加性融合} \end{cases} \quad (2)$$

因为边缘点的小波系数较大, 所以本文选择极大值融合。

Step(3) 定义  $2 \times 2$  为根窗口, 即  $2 \times 2$  为小波变换压缩的最小限度, 分别对  $4 \times 4$   $8 \times 8$  和  $16 \times 16$  窗口进行离散小波变换, 直至根窗口。每阶变换产生一个低尺度子带, 如果该窗口还没有压缩到根窗口, 则按式 (2) 进行系数选择并对融合后的子带继续分解。

Step(4) 遍历图像, 对每个像元分别计算 4 个不同尺度的空间特征, 得到 4 个不同尺度的根窗口信息。

Step(5) 对所有根窗口的小波系数作线性归一化, 便于输入分类器。

图 2 为多尺度特征提取的示例。

## 2.2 基于空间特征的 SVM 分类

支持向量机是建立在统计学习理论上的一种新的学习方法, 体现了学习过程的一致性和结构风险最小化原理, 其基本原理为:




图 2 空间邻域特征的小波压缩

Fig 2 Dimension reduction of spatial features based on wavelet

设训练样本为  $\{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$ , 其中,  $x_i \in R^d$ , 表示输入模式,  $y_i \in \{\pm 1\}$  表示目标输出。设最优决策面方程:  $w^T x_i + b = 0$  则权值向量  $w$  和偏置  $b$  须满足约束:

$$y_i (w^T x_i + b) \geq 1 - \xi_i \quad (3)$$

式中,  $\xi_i$  为线性不可分条件下的松弛变量, 它表示模式对理想线性情况下的偏离程度。根据决策面在训练数据上平均分类误差最小的准则, 可推导出以下优化问题:

$$\Phi(w, \xi) = \frac{1}{2} w^T w + C \sum_{i=1}^N \xi_i \quad (4)$$

式中,  $C$  是正则化参数, 表示 SVM 对错分样本的惩罚程度, 是错分样本比例和算法复杂度之间的平衡。用 Lagrange 乘子法, 最优决策面的求解可转化为以下的约束优化问题:

$$Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (5)$$

式中,  $\{\alpha_i\}_{i=1}^N$  为 Lagrange 乘子, 且 (5) 式满足约束条件:

$$\sum_{i=1}^N \alpha_i y_i = 0 \quad 0 \leq \alpha_i \leq C, \quad i = 1, 2, 3, \dots, N \quad (6)$$

$K(x, x_i)$  为核函数, 满足 Mercer 定理, 常用的核有以下两种: 多项式核:  $K = (x^T x_i + 1)^p$  和 RBF 核:  $K = \exp\left[-\frac{1}{2\sigma^2} \|x - x_i\|^2\right]$ 。根据高分辨率影像的特点, 由于类间方差较大, 同类地物样本的光谱特征较分散, 并非紧紧围绕着某些中心, 即高分辨率影像的光谱样本没有明显的中心, 而对于 RBF 核来说, 其对

于远离节点中心的样本输出几乎为零, 样本根据离中心距离的远近有不同的权重和响应值, 然而多项式核却不存在局域性, 所以它更适合作为高分辨率影像特征的核函数。

选择 SVM 作为空间特征的分类器, 是因为它无需特征空间正态分布的假设, 而且核空间的映射更适合多维的空间特征输入, SVM 提供的模型复杂度与输入特征维数无关, 这使得输入特征可以多元化, 核函数将输入特征映射到高维空间可能产生原始数据所不具备的新特征。

2 3 多尺度特征融合

高分辨率遥感影像中, 地物的细节充分展现, 它们的差异不仅仅表现在光谱上, 形状、大小、面积等特性均成为影像解译的重要因素。上文的算法得到了不同尺度下的分类结果, 每一个结果都是单一尺度的决策层描述。但地物分布的复杂性就在于它是多尺度的统一, 单尺度无法表达丰富的地面信息。所以, 本文提出多尺度特征融合算法, 旨在对 SVM 的多尺度分类结果在决策层进行融合, 根据地物的空间邻域特性, 在多尺度条件下寻求其最佳的决策。具体算法为:

(1) 把不同尺度的根窗口特征分别输入 SVM, 根据实际情况选择 SVM 的参数, 得到不同尺度下的

分类图 S2 S4 S8和 S16。

(2) 根据原始的高分辨率多光谱影像及多尺度分类图, 依据尺度选择因子  $C_i(x, y)$ , 为每个像元选择最佳决策结果, 其计算式为:

$$C_i(x, y) = \tau \frac{(w - 1) \cdot \max_i(\lambda_1, \lambda_2, \dots, \lambda_j \dots \lambda_n)}{\frac{1}{p} \sum_{m=1}^p \sigma_m}$$

(7)

式中,  $(x, y)$ 表示像元的行列号,  $i$ 表示 SVM 分类时的邻域窗口大小  $2 \times 2$   $4 \times 4$   $8 \times 8$ 和  $16 \times 16$   $w$ 为窗口  $i$ 内的像元总数,  $n$ 为地物类别数,  $\lambda_j$ 表示以  $(x, y)$ 为中心的窗口  $i$ 内第  $j$ 类地物的总数, 其计算是根据 S2 S4 S8和 S16的分类结果,  $p$ 是原始影像的波段数,  $\sigma_m$ 表示  $m$  ( $m = 1, 2, \dots, p$ )波段影像中以  $(x, y)$ 为中心的窗口  $i$ 内像元灰度方差的平方根,  $\tau$ 是比例调节系数, 便于尺度选择因子的比较。

(3) 遍历影像的每个像元, 逐像元计算其尺度选择因子  $C_i(x, y)$ , 每个像元得到 4 个尺度选择因子  $C_{2 \times 2}$   $C_{4 \times 4}$   $C_{8 \times 8}$ 和  $C_{16 \times 16}$

(4) 为每个像元选择最佳的分类结果, 设  $l(x, y)$ 表示像元  $(x, y)$  的最后决策类别, 其计算式为:

$$l(x, y) = \max_i \{C_i(x, y)\}$$

(8)

综上所述, 本文的多尺度融合与分类算法流程如图 3 所示。




图 3 多尺度融合与分类算法流程

Fig. 3 Algorithm flow chart of multiscale classification and fusion

3 实 验

3 1 QuickBird 数据实验

实验采用北京某地 QuickBird 影像的 3 个多光谱波段, 空间分辨率 2.44m, 大小  $288 \times 327$  如图 4 (a)所示, 图 4(b)是传统的单像素极大似然 (MLC) 分类, 图 4 (c)是单像素 SVM 分类, 图 4 (d)—图 4 (g)是不同尺度的分类结果, 图 4(h)是多尺度融合的结果。

精度统计采用混淆矩阵的 2 个统计量: Kappa 系数和 Overall 精度, 结果见表 1。

表 1 QuickBird 实验精度统计

Table 1 Accuracy estimation of QuickBird experiments

| 图 4     | (b)   | (c)   | (d)   | (e)   | (f)   | (g)   | (h)   |
|---------|-------|-------|-------|-------|-------|-------|-------|
| Overall | 0.756 | 0.797 | 0.835 | 0.823 | 0.849 | 0.868 | 0.886 |
| Kappa   | 0.718 | 0.752 | 0.793 | 0.786 | 0.811 | 0.835 | 0.857 |

图 4 和表 1 的结果表明, 空间邻域信息的加入可以改善分类精度, 但并非尺度 ( $i$ ) 越大分类精度越高, 如  $i=2$  的结果就优于  $i=4$  的结果, 尺度的选择由影像的分辨率及地物的特征决定。地物的形状、面积等几何特征的差异决定了单一尺度很难实现对多元化影像信息的描述, 图 4 (h) 的结果融合了多尺

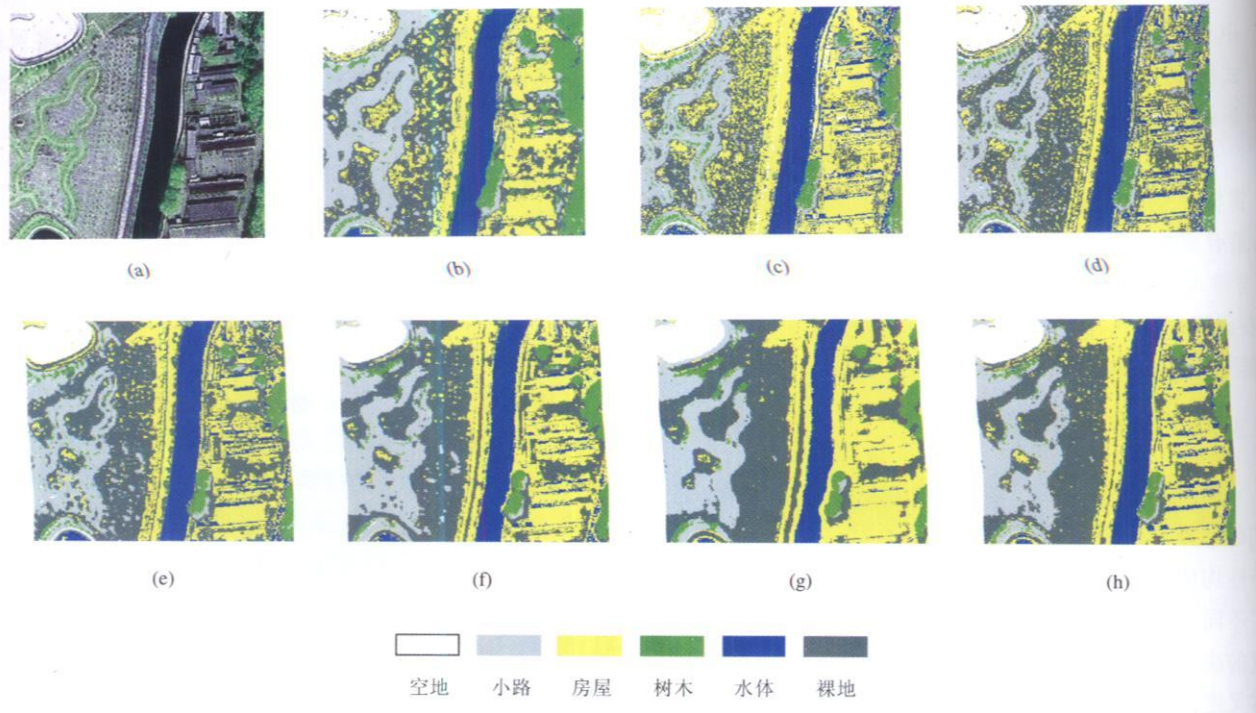


图 4 QuickBird数据实验结果

(a) RGB 影像; (b) 单像元分类图 (MLC); (c) 单像元分类图 (SVM); (d)  $i=2$  分类图;  
(e)  $i=4$  分类图; (f)  $i=8$  分类图; (g)  $i=16$  分类图; (h) 多尺度融合结果

Fig 4 Experimental results of QuickBird data

(a) RGB Image; (b) Classification map for single pixel (MLC); (c) Classification map for single pixel (SVM); (d) Classification map for  $i=2$   
(e) Classification map for  $i=4$  (f) Classification map for  $i=8$  (g) Classification map for  $i=16$  (h) Classification map based on multiscale fusion

度特征,其结果在保持对大面积地物分类的均一性的同时(如裸地、水体和房屋),减少了细节信息的丢失(如裸地上的树木、道路)。统计表明多尺度特征融合比逐像元多光谱分类方法在精度上有明显提高。为了说明多尺度融合的过程,图 5 列出了图 4(h)的尺度分布情况。




图 5 融合过程

Fig 5 Visualization of fusion process

图 5 中不同颜色表示融合结果的多尺度分布,可观察到:尺度最小 ( $i=2$ ) 的分类集中在影像的边缘;尺度最大 ( $i=16$ ) 的多为影像的内部点,是具有

分类均一性的大块地物,如房屋区,大片裸露地,河流等;尺度  $i=4$  的分类集中在边缘周围 2—3 个像素宽的带状区域,这是由于空间邻域的引入对大尺度在边缘处的分类形成窗口 (Window size) 效应,产生带状边缘,这一影响在图 4(g) 的  $16\times 16$  窗口分类中得到明显的反映,河岸的边缘扩大,河流变窄,所以在尺度选择后,这一区域的最佳尺度不可能很大,  $i=4$  的结果对该区域有最好的适应性。

3 2 Ikonos数据实验

为了进一步验证算法的有效性,本文用北京某地的 Ikonos 全色波段进行实验,影像空间分辨率为 1m,大小  $434\times 377$  实验结果如图 6 所示。

实验的精度统计见表 2 融合过程如图 7 所示。

表 2 Ikonos实验精度统计

Tab 2 Accuracy estimation of Ikonos experiments

| 图 6     | (b)   | (c)   | (d)   | (e)   | (f)   | (g)   |
|---------|-------|-------|-------|-------|-------|-------|
| Overall | 0.627 | 0.667 | 0.715 | 0.788 | 0.816 | 0.825 |
| Kappa   | 0.523 | 0.573 | 0.634 | 0.723 | 0.755 | 0.766 |



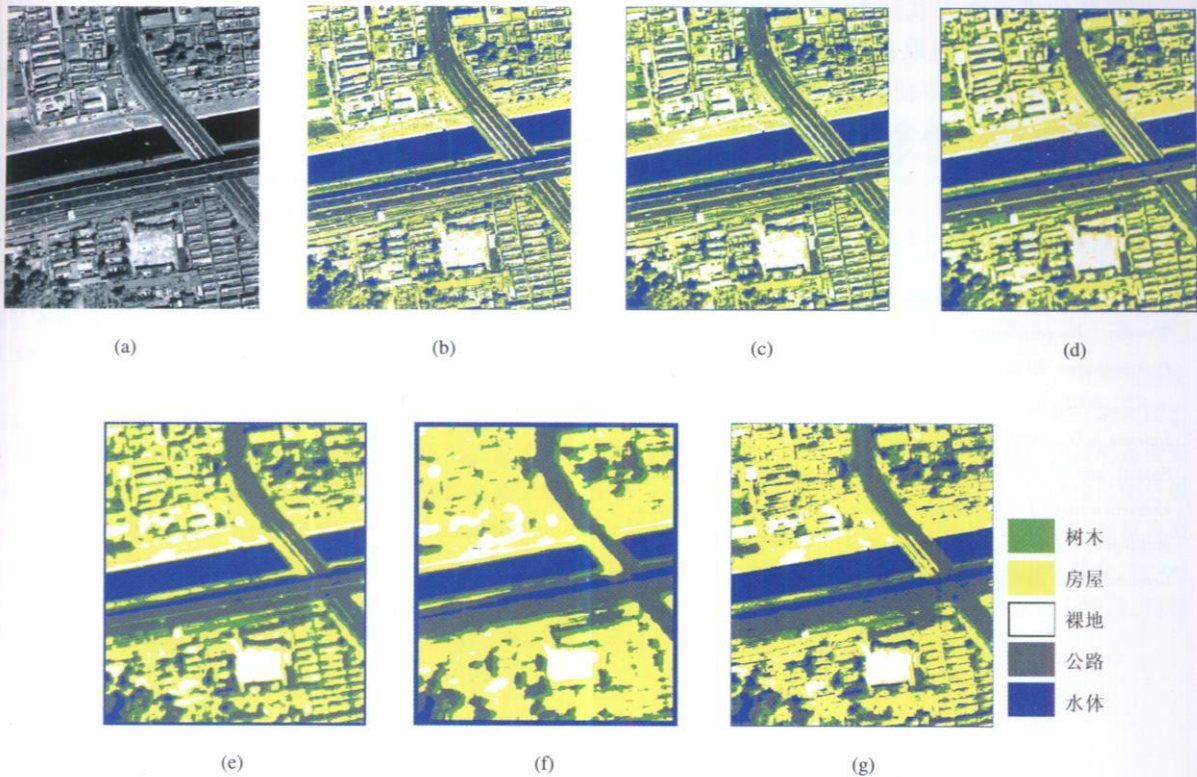


图 6 KONOS数据实验结果  
(a) KONOS 全色波段; (b) 单像素最小距离分类; (c)  $i=2$  分类图; (d)  $i=4$  分类图;  
(e)  $i=8$  分类图; (f)  $i=16$  分类图; (g) 多尺度融合结果

Fig 6 Experimental results of KONOS data

(a) KONOS Pan channel (b) Classification map for single pixel (c) Classification map for  $i=2$  (d) Classification map for  $i=4$   
(e) Classification map for  $i=8$  (f) Classification map for  $i=16$  (g) Classification map based on multiscale fusion




图 7 融合过程

Fig 7 Visualization of fusion process

结果与 QuickBird实验相似, 多尺度融合的结果比单像素多光谱分类方法在精度上有明显提高, 多尺度融合算法顾及到了不同尺度地物的特性, 融合结果(图 6(g))在保持大面积地物分类均一性的同时, 减少了小尺度地物细节信息的丢失。从分类结

果可知, 空间邻域介入分类器增强了决策过程中相邻像素的相关性, 和逐像素分类相比, 本文的算法考虑了多尺度的邻域知识, 提高了分类器对不同尺度地物的适应性, 减弱了逐像素分类的椒盐效应。

4 结论与展望

本文针对传统的逐像素光谱分类方法的不足, 提出多尺度特征融合算法, 旨在提高高分辨率遥感影像解译的精度。该算法用不同的邻域窗口提取影像的多尺度信息, 用小波变换压缩邻域信息, 以减少空间特征的维数, 并通过小波系数的融合保留了区域的细节信息, 然后把多尺度空间特征逐一输入支持向量机, 得到不同尺度的分类图, 最后根据尺度选择因子对分类结果进行决策层融合。实验表明, 该算法能有效利用高分辨率影像的邻域信息提高分类精度。

本算法有待完善的问题是: (1)尺度在空间的变化是连续的, 其离散化的等级相隔越大, 多尺度特

征对不同地物的描述能力就越差, 下一步可研究基于连续尺度的空间特征提取; (2)影像的空间特征提取往往是基于单波段, 特征扩展到多波段通常维数较高, 如何提取多波段影像的空间特征也是值得研究的。

参 考 文 献 (References)

[ 1 ] Myint SW, Lan N SN, Tylor J. An Evaluation of Four Different Wavelet Decomposition Procedures for Spatial Feature Discrimination Within and Around Urban Areas[ J]. *Transactions in GIS*, 2002, 6( 4): 403— 429

[ 2 ] Jimenez L O, Medina J L R, Diaz E R, *et al*. Integration of Spatial and Spectral Information by means of Nnsupervised Extraction and Classification for Homogeneous Objects Applied to Multispectral and Hyperspectral Data[ J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43( 4): 844— 851.

[ 3 ] Christodoulos J, Silas G, Constantinos S. Multifeature Texture Analysis for the Classification of Clouds in Satellite Imagery[ J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2003, 41( 11): 2662— 2668.

[ 4 ] Kontoes C G, Raptis V. The Potential of Kernel Classification Techniques for Land Use Mapping in Urban Areas Using 5M-spatial Resolution IRS-1C Imagery[ J]. *Int. J. Remote Sensing*, 2000, 21( 16): 3145— 3151.

[ 5 ] Bamsley M J, Barr S L. Inferring Urban Land Use From Satellite Sensor Using Kernel-based Spatial Reclassification [ J]. *Photogrammetric Engineering & Remote Sensing*, 1996, 62( 7): 949— 958

[ 6 ] Chen Q X, Luo J G, Zhou C H, *et al*. Classification of Remotely Sensed Imagery Using Multi features Based Approach [ J]. *Journal of Remote Sensing*, 2004, 8( 3): 239— 245 [ 陈秋晓, 骆剑承, 周成虎等. 基于多特征的遥感影像分类方法[ J]. 遥感学报, 2004, 8( 3): 239— 245.